

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# **ZAVRŠNI RAD**

**Domagoj Lučić Pech**

Zagreb, 2018 godina.

# ZAVRŠNI RAD

Mentor:

Prof. dr. sc. Dubravko Majetić

Student:

Domagoj Lučić Pech

Zagreb, 2018. godina.

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvaljujem se mentoru prof.dr.sc. Dubravku Majetiću na strpljenju, podršci i korisnim savjetima pruženim tijekom izrade ovog završnog rada.

Zahvaljujem se dr.sc. Tomislavu Staroveškom i prof.dr.sc. Danku Brezaku na vremenu, podršci i ustupljenom znanju bez kojih izrada ovog rada ne bi bila moguća.

Na kraju se zahvaljujem obitelji i djevojci na bezuvjetnoj podršci.

Domagoj Lučić Pech



SVEUČILIŠTE U ZAGREBU  
**FAKULTET STROJARSTVA I BRODOGRADNJE**



Središnje povjerenstvo za završne i diplomske ispite  
Povjerenstvo za završne ispite studija strojarstva za smjerove:  
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo  
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

## ZAVRŠNI ZADATAK

Student: Domagoj Lučić Pech Mat. br.: 0035201210

Naslov rada na hrvatskom jeziku: Nadzor stupnja delaminacije kod bušenja polimernog kompozita ojačanog staklenim vlaknima

Naslov rada na engleskom jeziku: Delamination monitoring of glass fiber reinforced polymer (GFRP) during drilling

Opis zadatka:

Suvremeni trendovi u raznim granama industrije ukazuju na sve veću primjenu kompozitnih materijala. Pritom je obrada bušenjem jedna od najčešćih operacija obrade odvajanjem. Ključni problem kod bušenja kompozitnih materijala je pojava delaminacije ili raslojavanja, koja većim dijelom ovisi o geometriji i stupnju istrošenosti reznog alata te parametrima obrade. Raslojavanje smanjuje mehanička svojstva materijala u zoni obrade, a dugoročno može nepovoljno utjecati na trajnost i krutost obrađene pozicije.

U radu treba načiniti sljedeće:

1. Kvantificirati stupanj delaminacije iz slika provrta izbušenih različitim kombinacijama parametara obrade i alatima različitog stupnja istrošenosti.
2. Razviti programsku podršku za filtriranje i obradu snimljenih sila rezanja.
3. Iz pripremljenih signala izdvojiti odgovarajuće značajke procesa.
4. Izraditi programsku podršku za neuronsku mrežu koja će prema značajkama procesa biti primijenjena u klasifikaciji stupnja delaminacije.
5. Analizirati utjecaj svih izdvojenih značajki procesa i njihovih kombinacija na kvalitetu procjene stupnja delaminacije.
6. Izvesti zaključke rada.

Zadatak zadan:

30. studenog 2017.

Zadatak zadao:

Prof. dr. sc. Dubravko Majetić

Rok predaje rada:

1. rok: 23. veljače 2018.

2. rok (izvanredni): 28. lipnja 2018.

3. rok: 21. rujna 2018.

Predviđeni datumi obrane:

1. rok: 26.2. - 2.3. 2018.

2. rok (izvanredni): 2.7. 2018.

3. rok: 24.9. - 28.9. 2018.

Predsjednik Povjerenstva:

Izv. prof. dr. sc. Branko Bauer

## Sadržaj

Popis slika .....	II
Popis tablica .....	III
Popis oznaka.....	IV
Sažetak .....	V
Summary .....	VI
1. Uvod .....	1
2. Kompozitni materijali.....	2
2.1 Kompoziti s polimernom matricom .....	4
2.2 Kompoziti ojačani staklenim vlaknima.....	5
3. Obrada kompozita.....	6
3.1 Bušenje.....	6
3.2 Parametri obrade kod bušenja .....	6
4. Neuronske mreže .....	7
4.1 Statičke neuronske mreže.....	8
5. Pregled dosadašnjih radova .....	10
5.1 Snimanje signala sila rezanja .....	12
6. Obrada podataka .....	14
6.1 Kvantificiranje stupnja delaminacije.....	14
6.2 Sile rezanja .....	18
6.3 Stupanj istrošenosti alata.....	20
6.4 Klasifikacija stupnja delaminacije .....	25
6.5 Izrada neuronske mreže .....	25
6.6 Rezultati učenja neuronske mreže.....	28
7. Zaključak .....	30
8. Literatura.....	31

## Popis slika

Slika 1. Primjer slojeva u kompozitnom materijalu [4] .....	3
Slika 2. Primjer unutrašnje sturkture polimernog kompozita s ugljični vlaknima [7] .....	4
Slika 3. Prikaz mogućih rasporeda vlakana [8] .....	5
Slika 4. Način izrade staklenih vlakana [9] .....	5
Slika 5. Prikaz glavnih gibanja kod bušenja [10] .....	6
Slika 6. Prikaz raspodjele brzine rezanja po promjeru svrdla [10] .....	6
Slika 7. Struktura umjetnog neurona [11] .....	7
Slika 8. Nelinearna bipolarna sigmoidalna funkcija [11] .....	8
Slika 9. Model statičke neuronske mreže [11] .....	9
Slika 10. Shematski prikaz postupka namatanja vlakana [12] .....	10
Slika 11. Radionički crtež svrdla A1163, Walter Titex [12] .....	11
Slika 12. Određivanje trošenja svrdla [12] .....	12
Slika 13. Nabojno pojačalo Kistler 5017B [12] .....	12
Slika 14. Senzor sila Kistler 9257B [12] .....	13
Slika 15. Izlazna (lijevo) i ulazna (desno) strana provrta .....	14
Slika 16. Kvantificiranje stupnja delaminacije .....	15
Slika 17. Postupak određivanja površine delaminacije [12] .....	15
Slika 18. Srednja udaljenost točaka .....	16
Slika 19. Opseg delaminacije .....	17
Slika 20. Površina delaminacije .....	17
Slika 21. Maksimalna udaljenost između točaka .....	18
Slika 22. Značajke Max Fz i Max Fr .....	19
Slika 23. Značajke Surf Fd i Surf Fr .....	20
Slika 24. Značajke SPL Fy i SPL Fx .....	20
Slika 25. Normalna distribucija delaminacije po stupnjevima istrošenosti alata .....	21
Slika 26. Srednji iznos delaminacije po stupnjevima istrošenosti S1 i S2 .....	22
Slika 27. Srednji iznos delaminacije po stupnjevima istrošenosti S3 i S4 .....	22
Slika 28. Srednji iznos delaminacije po stupnjevima istrošenosti S2 i S3 .....	23
Slika 29. Normalna distribucija delaminacije po korigiranim stupnjevima istrošenosti alata .....	24
Slika 30. Srednji iznos delaminacije po korigiranim stupnjevima istrošenosti S1 i S2 .....	24
Slika 31. Površina delaminacije po uzorku s posmakom 0,03 mm/okr i brzinom rezanja 45 m/min .....	25
Slika 32. Arhitektura upotrebene neuronske mreže .....	28
Slika 33. Rast klasifikacijske točnosti po broju koraka do maksimalne vrijednosti .....	29

**Popis tablica**

Tablica 1 Stupnjevi istrošenosti svrdla i pripadajući broj probušenih provrta [12] .....	10
Tablica 2. Osnovne tehničke karakteristike mjernog sustava sila rezanja [12] .....	13
Tablica 3. Oznake i opisi značajki izdvojenih iz signala sila [12] .....	19
Tablica 4. Srednje vrijednosti delaminacije po stupnju istrošenosti alata .....	21
Tablica 5. Parametri neuronske mreže .....	27

---

**Popis oznaka**

$d$	promjer svrdla
$E$	matrica pogreške
$f$	posmak
$F_d$	rezultantna sila rezanja u radijalnom smjeru
$F_r$	rezultantna sila rezanja
$F_x$	komponenta rezultantne sile rezanja u smjeru X osi
$F_y$	komponenta rezultantne sile rezanja u smjeru Y osi
$F_z$	komponenta rezultantne sile rezanja u smjeru Z osi
$n$	učestalost vrtnje, broj koraka
$net_H$	vektor suma ulaza skrivenih neurona
$net_O$	vektor suma ulaza izlaznog sloja
$O$	vektor izlaza mreže
$v_c$	brzina rezanja
$v$	matrica težina skrivenog sloja
$w$	matrica težina izlaznog sloja
$y$	matrica izlaza skrivenih neurona
$\alpha$	parametar momentuma prvog reda
$\lambda$	koeficijent regularizacije
$\eta$	parametar učenja
$\Delta v$	iznos promjene težina skrivenog sloja
$\Delta w$	iznos promjene težina izlaznog sloja
$\nabla_v$	matrica gradijenta težina skrivenog sloja
$\nabla_w$	matrica gradijenta težina izlaznog sloja



## **Sažetak**

Kompozitni materijali su relativno nova vrsta materijala vrlo popularna zbog svojih iznimnih svojstava. Najzastupljeniji postupci proizvodnje rezultiraju izradcima koji zahtjevaju relativno malo dodatne obrade uz iznimku postupka obrade odvajanjem čestica tj. bušenje. Prilikom izrade provrta kod određenih tipova kompozita dolazi do raslojavanja (delaminacije) slojeva u kompozitu što nepovoljno utječe na mehanička i druga svojstva kompozita. U ovom završnom radu su obrađeni podaci dobiveni bušenjem provrta u polimernom kompozitu sa staklenim vlaknima te je zatim izrađena programska podrška za neuronsku mrežu koja na osnovu mjerenih značajki sila te parametara obrade klasificira stupanj delaminacije.

Ključne riječi: delaminacija, raslojavanje, neuronska mreža, polimerni kompoziti, klasifikacija.

## **Summary**

Composite materials are a relatively new type of material which is very popular due to their extraordinary properties. The most common procedures of manufacturing result in products that require relatively little additional machining with the exception of drilling. Delamination occurs during hole drilling in certain types of composites which negatively impacts the mechanical and other properties. Data collected during drilling of holes in polymer composites with glass fibers reinforcement was processed in this undergraduate thesis and then program support for a neural network was developed. The neural network will classify the resulting delamination from measured forces and the parameters of drilling.

Key words: delamination, neural network, polymer composites, classification.

## 1. Uvod

U potrazi za materijalima sve boljih i boljih svojstava mnoge industrije su prepoznale potencijal kompozitnih materijala te kao rezultat toga njihova proizvodnja i uporaba bilježi veliki porast. Kompoziti pružaju mogućnost postizanja kombinacije svojstava teško ostvarivih pomoću drugih materijala, npr. otpornost na povišene temperature, visoka tvrdoća i čvrstoća, mala masa, otpornost na koroziju i slična svojstva. Kompoziti s keramičkom i metalnom matricom su većinom korišteni u specijalnim primjenama, dok kompoziti s polimernom matricom nalaze širok spektar primjene, pogotovo u zrakoplovnoj, automobilskoj i vojnoj industriji. Procesi proizvodnje polimernih kompozita (npr. pultruzija, namotavanje, kalupljenje itd.) u većini slučajeva omogućuju proizvodnju oblika koji zahtjeva relativno malo dodatne obrade. Jedna od najčešćih operacija dodatne obrade je bušenje provrta, a podatak koji govori o njihovoj zastupljenosti je da je za izradu modernog putničkog zrakoplova potrebno napraviti preko milijun provrta.

Ključan problem prilikom bušenja kompozitnih materijala je pojava raslojavanja tj. delaminacije, koja ovisi o parametrima obrade, geometriji i stupnju istrošenosti svrdla, te o sastavu samog materijala. Raslojavanje ima velik utjecaj na mehanička svojstva materijala u zoni obrade, trajnost materijala i pojavu pukotina. Trud koji se ulaže u suzbijanju ove pojave pokazuju brojna provedena istraživanja. Cilj ovog završnog rada je obraditi podatke iz jednog takvog istraživanja, odrediti bitne značajke te načiniti neuronsku mrežu koja će na osnovu parametara rezanja, te određenih mjerenih signala klasificirati stupanj delaminacije.

## 2. Kompozitni materijali

Kompozitni materijali ili ukratko kompoziti su materijali proizvedeni umjetnim spajanjem dvaju ili više materijala različitih svojstava s ciljem dobivanja materijala takvih svojstava kakva ne posjeduje niti jedna komponenta sama za sebe. [1]

Neke od osnovnih prednosti kompozitnih materijala u odnosu na druge široko korištene materijale su : nove kombinacije svojstava, mogućnost izrade vrlo složenih oblika, smanjenje troškova naknadne obrade dijelova, mogućnost spajanja dijelova tijekom izrade, dimenzijska stabilnost pri ekstremnim uvjetima rada te mogućnost postizanja važnih svojstava poput otpornosti na koroziju, zamor te otapanje, visoka tvrdoća, velike vrijednosti modula elastičnosti te granice tečenja u odnosu na gustoću. Neki nedostaci su anizotropija, heterogenost, visoka cijena i slaba mogućnost recikliranja. [2]

Postoje dvije glavne kategorije konstitutivnih elemenata kompozita: matrice i ojačala. Matrice su najčešće metalne, keramičke ili polimerne, dok ojačala po obliku mogu biti čestice, vlakna ili strukturni kompoziti.

Zadaća matrica je da : [3]


- drži ojačala zajedno
- štiti ih od vanjskih utjecaja
- prenosi opterećenje na ojačalo
- daje vanjsku formu kompozitu
- određuje njegovo ponašanje s obzirom na djelovanje vanjskih uvjeta ( atmosfera, korozija)

Pritom je zadaća ojačala da bude nosivi element kompozita i da osigura: [3]

- visoku čvrstoću
- visoki modul elastičnosti-krutost
- otpornost na trošenje

Ukupno ponašanje kompozita ovisi o:

1. svojstvima matrice i ojačala
2. veličini i rasporedu odnosno raspodjeli konstituenata
3. volumnom udjelu konstituenata
4. obliku konstituenata
5. prirodi i jakosti veze među konstituentima



**Slika 1. Primjer slojeva u kompozitnom materijalu [4]**

Širok spektar primjene i popularnost u mnogobrojnim područjima kompozitni materijali mogu zahvaliti svojim iznimnim svojstvima. Nalaze redovitu primjenu tamo gdje se traži mala težina, a da pritom materijal pri teškim uvjetima rada zadržava svojstva poput otpornosti na visoke temperature, otpornosti na koroziju, velika čvrstoća i tvrdoća i sl.

Neka od područja primjene su: svemirska tehnika, zrakoplovna industrija, energetika i elektrotehnika, građevinarstvo, brodogradnja te opće strojarstvo gdje se koriste kao materijali za oplata, izolacije, cijevi, spremnike, kućišta, okvire, dijelove sportskih vozila.

## 2.1 Kompoziti s polimernom matricom

Kompoziti s polimernom matricom zahvaljujući svojim prednostima imaju najrašireniju primjenu u gotovo svim granama industrije. Povoljna svojstva uključuju: visoka specifična čvrstoća, visoka krutost, mala gustoća u odnosu na druge materijale, otpornost na različite medije, mogućnost izrade složenih oblika, niski troškovi naknadne obrade te dimenzijska stabilnost u ekstremnim radnim uvjetima.


Dok su neki od nedostataka: niska otpornost na visoke temperature te veliki koeficijent toplinske ekspanzije [5] [6].

Sastavljeni su od polimerne smole kao matrice s vlaknima kao komponentom za ojačavanje.

S obzirom na tip vlakana se dijele na: [1]

- staklenim vlaknima ojačani polimerni kompoziti
- ugljičnim vlaknima ojačani polimerni kompoziti
- aramidnim vlaknima ojačani polimerni kompoziti
- te ostali vlaknasti materijali za ojačanje

Pojam „smola“ u ovom se kontekstu koristi za obilježavanje polimerne tvari visoke molekularne mase koju treba ojačati. Najraširenije i daleko najjeftinije polimerne smole su poliesteri i vinil esteri te se primjenjuju kod staklenim vlaknima ojačanim polimernim kompozitima. Epoksidne smole znatno su skuplje te su često neprikladne za komercijalnu uporabu. Najčešće se koriste u zrakoplovstvu. Za visokotemperaturne primjene koriste se poliamidi i drugi visokotemperaturni plastomeri. [1]



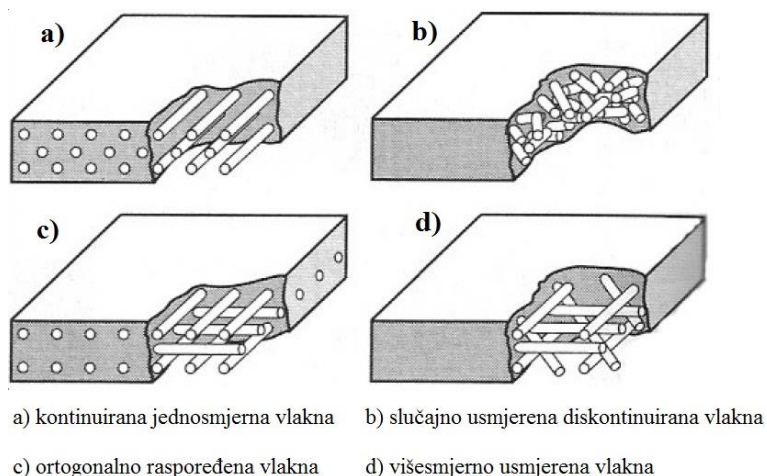
Slika 2.Primjer unutrašnje sturkture polimernog kompozita s ugljični vlaknima [7]

## 2.2 Kompoziti ojačani staklenim vlaknima

Najrašireniji tip kompozita ojačan sa staklenim vlaknima, kontinuiranim ili diskontinuiranim, koja se nalaze u polimernoj matrici. Staklo je popularan materijal za ojačavanje zbog nekoliko razloga: lako ga je izvući u vlakna, lako ga se dobavlja te ga se ekonomično kombinira s kompozitom, imaju vrlo veliku specifičnu čvrstoću te su kemijski inertni. [1]

Ipak postoji nekoliko ograničenja pri korištenju ovog materijala, a to su:

- niska krutost
- mala maksimalna temperatura primjene
- površinsko tečenje
- anizotropija ako su vlakna jednosmjerna i opterećenje djeluje okomito



**Slika 3. Prikaz mogućih rasporeda vlakana [8]**




**Slika 4. Način izrade staklenih vlakana [9]**

### 3. Obrada kompozita

#### 3.1 Bušenje


Bušenje je postupak obrade odvajanjem čestica koji se koristi za bušenje provrta malih dimenzija ili proširivanje provrta većih promjera, pri čemu razlikujemo provrt i uvt. Glavno gibanje je kružno kontinuirano, a posmično je pravolinijsko kontinuirano. Alat upotrebljivan za bušenje je svrdlo, najčešće standardno spiralno svrdlo s dvije glavne oštrice i jednom poprečnom. Na slici 5 je prikazano glavno gibanje G i posmično gibanje P.



Slika 5. Prikaz glavnih gibanja kod bušenja [10]

#### 3.2 Parametri obrade kod bušenja

Osnovni parametri kod bušenja su posmak ( $f$ ), brzina rezanja ( $v_c$ ) i učestalost vrtnje ( $n$ ). Posmak je udaljenost koju svrdlo prijeđe u smjeru osi alata za jedan okretaj alata. Brzina rezanja se mijenja linearno duž rezne oštrice. U osi svrdla je jednaka nuli, dok je na obodu maksimalnog iznosa.

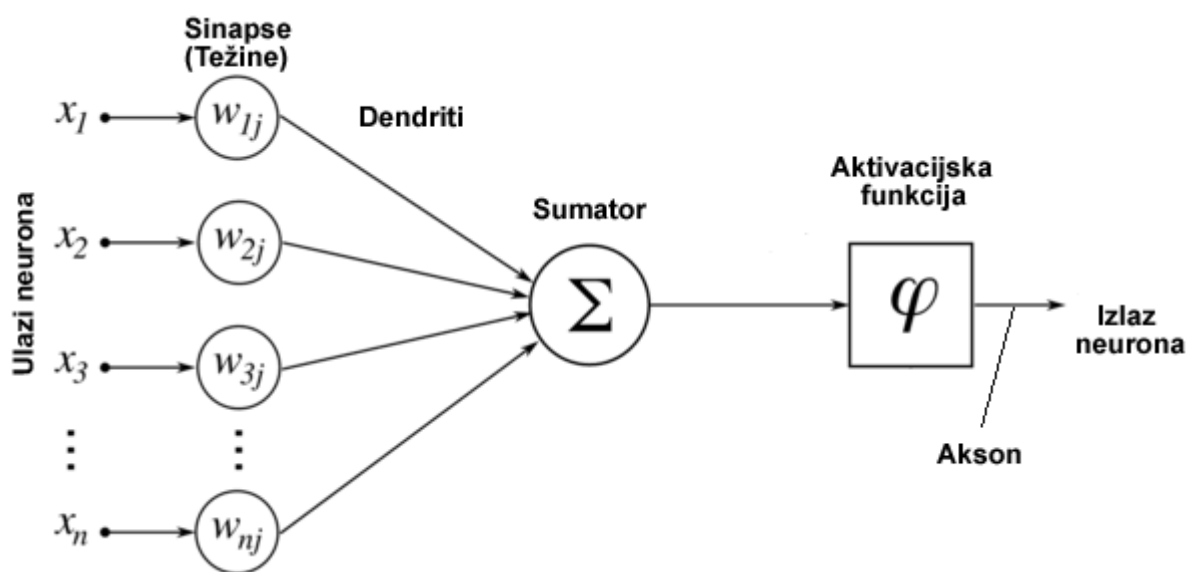


Slika 6. Prikaz raspodjele brzine rezanja po promjeru svrdla [10]



#### 4. Neuronske mreže

Umjetne neuronske mreže su računalni sustavi inspirirani biološkim modelom neurona čija je uloga procesiranje podataka tj. oponašanje osnovne funkcije biološkog neurona, a podjedinica je umjetni neuron čiji je primjer prikazan na slici 7. U usporedbi s biološkim neuronom, tijelo neurona se zamjenjuje sumatorom, dendriti se zamjenjuju ulazima neurona, akson se zamjenjuje izlazom neurona dok je aktivacijska funkcija zamjena za prag osjetljivosti biološkog neurona.




Slika 7. Struktura umjetnog neurona [11].

Neuronske mreže se mogu podijeliti po broju slojeva, jednoslojne i višeslojne, gdje se sloj definira kao paralelno složen skup neurona. U pravilu svaka neuronska mreža ima ulazni i izlazni sloj, a između njih takozvane skrivene slojeve. Ako su slojevi povezani tako da signali putuju u samo jednom smjeru, onda je riječ o unaprijednim neuronskim mrežama. Ukoliko postoji barem jedna povratna petlja sa suprotnim smjerom signala, onda govorimo o povratnoj neuronskoj mreži. Također se mogu podijeliti po načinu učenja, supervizorno (uz nadzor) te nesupervizorno (bez nadzora) [11]. Tri vrste mreža koje su najviše istraživane i koje se najviše primjenjuju u praksi su unaprijedne statičke neuronske mreže, dinamičke neuronske mreže te mreže s radijalnim baznim funkcijama (RBF).

#### 4.1 Statičke neuronske mreže

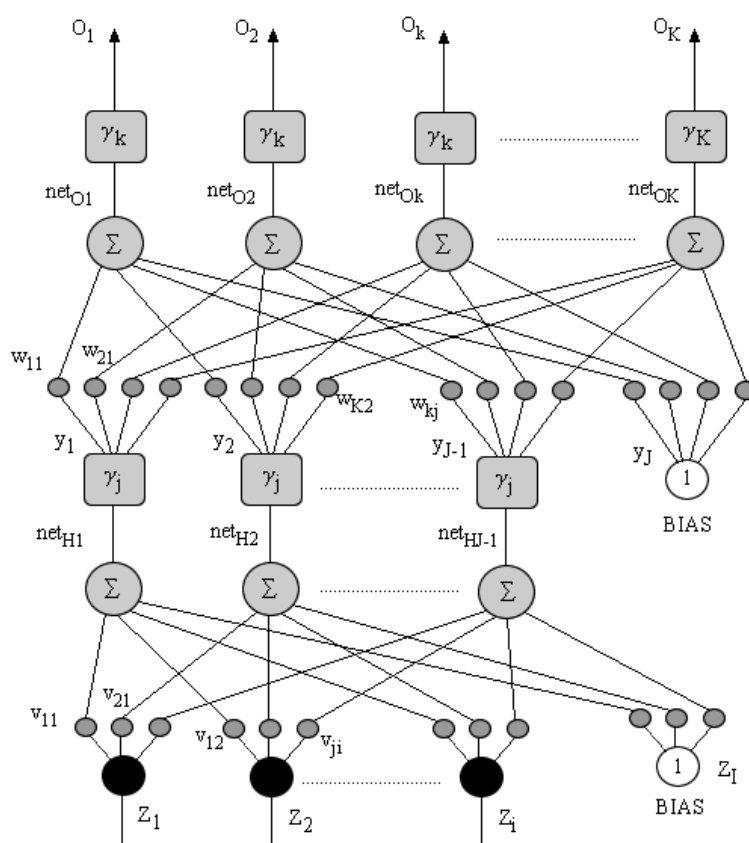
Najpoznatiji i najčešće upotrebljivan tip mreže koji je primjenjen i u sklopu ovog rada. Kao što je prikazano na slici 7, umjetni neuron sumira sve ulaze pomnožene s određenom težinom  $w$ , sumu predaje na ulaz aktivacijske funkcije čiji rezultat je izlaz neurona. Najčešća aktivacijska funkcija je nelinearna bipolarna sigmoidalna aktivacijska funkcija prikazana na slici 8.



Slika 8. Nelinearna bipolarna sigmoidalna funkcija [11]

Više umjetnih neurona se spaja na način prikazan na slici 9 gdje su:

$O_k$	k-ti izlaz iz mreže
$net_{Ok}$	suma ulaza k-tog izlaznog neurona
$w_{kj}$	težina izlaza j-tog neurona skrivenog sloja prema k-tom izlazu
$net_{Hj}$	funkcija suma ulaza j-tog neurona skrivenog sloja
$v_{ji}$	težina izlaza i-tog ulaznog neurona prema j-tom skrivenom neuronu
$Z_i$	i-ti ulaz u mrežu




Slika 9. Model statičke neuronske mreže [11]

U procesu učenja mreži se za svaki uzorak za vježbu daje ulaz te se dobije izlaz iz mreže koji se uspoređuje sa željenim izlazom. Greška se dobije oduzimanjem dobivene vrijednosti od željene za svaki izlazni neuron. Povratnim prostiranjem ove greške kroz cijelu strukturu mreže se želi minimizirati određenu funkciju cilja što će približavati iznos na izlazu iz mreže onom željenom za određeni uzorak. Na kraju se naučenu neuronsku mrežu testira na podacima za testiranje jer učinak mreže na podacima s kojim je učena često nije dobar pokazatelj primjenjivosti mreže.

## 5. Pregled dosadašnjih radova

Cilj ovog završnog rada je kvantificirati stupanj delaminacije uz pomoć neuronske mreže. U tu svrhu su iskorišteni podaci dobiveni u [12] gdje je osmišljen pokus bušenja kompozita i proveden u Laboratoriju za alatne strojeve Fakulteta strojarstva i brodogradnje u Zagrebu. Pokus se provodio na ispitnim uzorcima dimenzije 180x100x10 mm izrezanim iz kompozitne cijevi izuzete iz proizvodnje tvrtke Domitran. Materijal cijevi je kompozit sa polimernom matricom (nezasićena poliesterska smola) ojačan staklenim vlaknima s udjelom od oko 60%. Cijev je izrađena postupkom namatanja kontinuiranih vlakana na rotirajući kalup, prikazan na slici

10




**Slika 10. Shematski prikaz postupka namatanja vlakana [12]**

Pri izvođenju pokusa korišteno je svrdlo izrađeno od tvrdog metala, model A1163, proizvođača Walter Titex. Promjer svrdla je 6 mm, vršnog kuta 118°, dok su ostale dimenzije prikazane na slici 11. Ispitana su 4 stupnja istrošenosti navedenog svrdla s detaljnim prikazom u tablici.

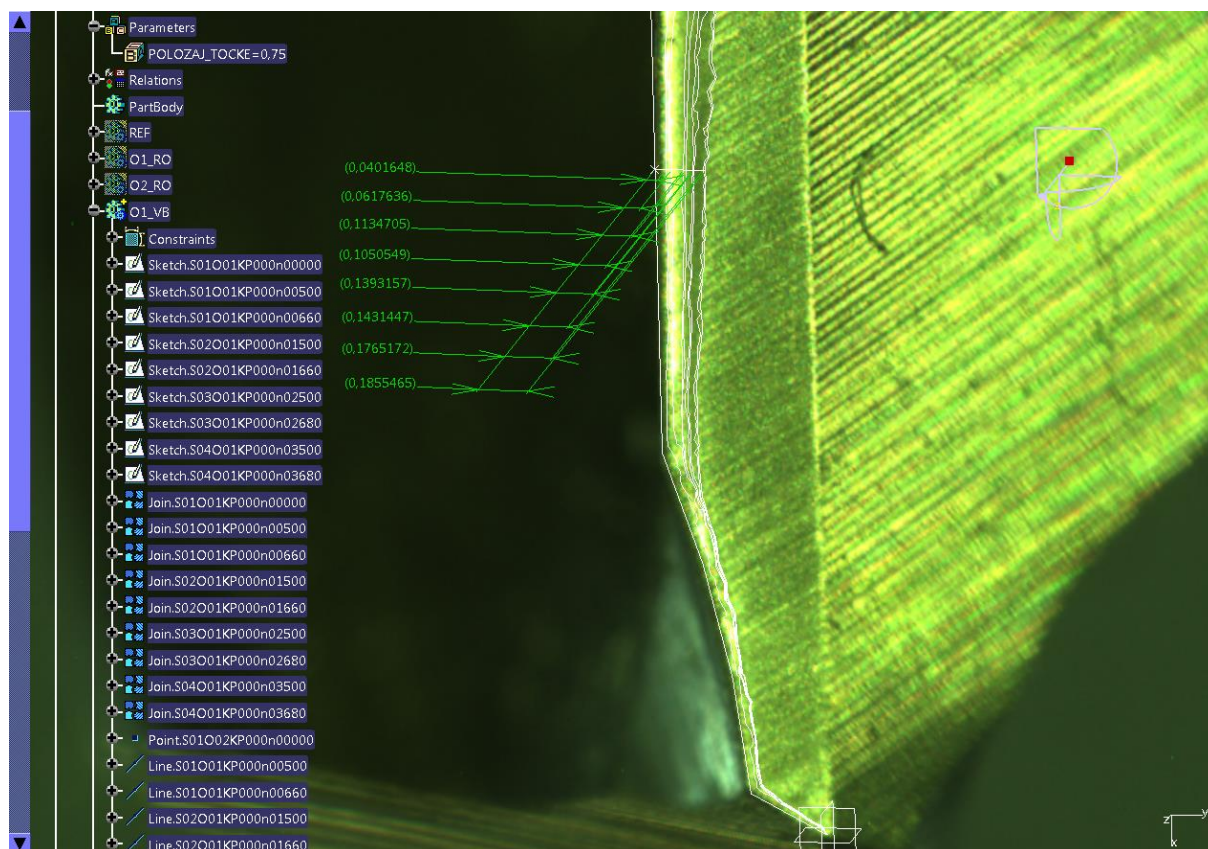
**Tablica 1 Stupnjevi istrošenosti svrdla i pripadajući broj probušenih provrta [12]**

Stupanj istrošenosti svrdla	S1	S2	S3	S4
Broj izbušenih provrta	500-660	1500-1660	2500-2660	3500-3660



Slika 11. Radionički crtež svrdla A1163, Walter Titex [12]

U planu pokus odabrane su 4 brzine rezanja i 4 posmaka, što je zajedno dalo 16 kombinacija posmaka i brzine rezanja. Svaka od 16 kombinacija je ponavljana 10 puta za svaki od sveukupno 4 stupnja istrošenosti za ukupno 640 uzoraka. Tijekom izvođenja pokusa kontinuirano su snimani određeni signali, a periodički je slikana i rezna oštrica. Nakon bušenja, industrijskom kamerom su fotografirane ulazne i izlazne strane provrta. Istrošenost svrdla se direktno određivala na temelju fotografija oštrica reznog alata, a to je prikazano na slici 12.



Slika 12. Određivanje trošenja svrdla [12]

### 5.1 Snimanje signala sila rezanja

U [12] za mjerenje signala sila korišten je tro-komponentni piezo-električni senzor sila proizvođača Kistler Holding AG, model 9257B u kombinaciji s odgovarajućim nabojnim pojačalom proizvođača Kistler Holding AG, model 5017B.



Slika 13. Nabojno pojačalo Kistler 5017B [12]



Slika 14. Senzor sila Kistler 9257B [12]

Tehničke karakteristike mjernog sustava su prikazane u tablici 2.

Tablica 2. Osnovne tehničke karakteristike mjernog sustava sila rezanja [12]


			Područje	Jedinica
Senzor sila (tip 9257B)	Mjerno područje	$F_x, F_y$	-5 ... 5	kN
		$F_z$	-5 ... 10	
	Maksimalne dozvoljene sile	$F_x, F_y$	-7,5/7,5	
		$F_z$	-7,5/15	
	Osjetljivost	$F_x, F_y$	-7,5	pC/N
		$F_z$	-3,7	
	Prag osjetljivosti		<0,01	N
Nabojno pojačalo (tip 5017B)	Linearnost u mjernog područja		<±1	%
	Prag histereze mjernog područja		<0,5	%
	Broj kanala		3 (do 8)	
	Mjerno područje (podesivo po kanalu)		±10 ... 10 <sup>6</sup>	pC
	Frekvencijsko područje		0 ... 200	kHz
	Osjetljivost (podesiva po kanalu)		0,01 ... 9990	pC/N
	Skaliranje mjerne veličine (podesivo po kanalu)		0,001 ... 10 <sup>7</sup>	N/V
	Izlazni signal (po kanalu)		±10	V

Signali sila su snimani u smjeru X, Y i Z osi uz pomoć navedenog mjernog sustava s frekvencijom uzorkovanja 1 kHz. Signali su analizirani u vremenskom i frekvencijskom području. Rezultantna sila je dobivena prema izrazu:  $\mathbf{F_r} = \sqrt{\mathbf{F_x^2} + \mathbf{F_y^2} + \mathbf{F_z^2}} \text{ [N]}$ , dok je rezultantna sila u radijalnom smjeru izračunata prema izrazu:  $\mathbf{F_d} = \sqrt{\mathbf{F_x^2} + \mathbf{F_y^2}} \text{ [N]}$ .

## 6. Obrada podataka

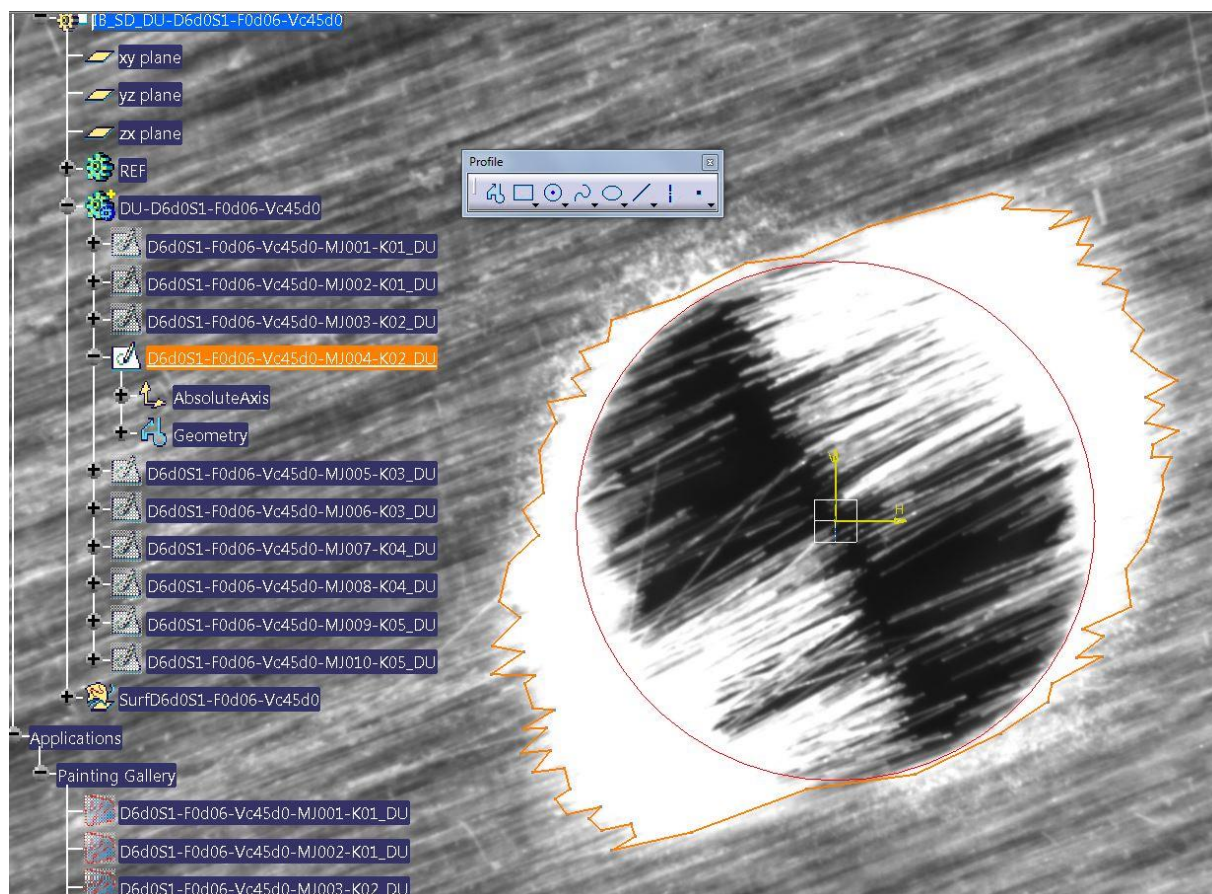
### 6.1 Kvantificiranje stupnja delaminacije

Stupanj delaminacije je kvantificiran prema fotografijama provrta iz [12] uz pomoć programskog paketa Catia V5R20. U prvom koraku su ručno iscrtavane konture delaminacije na svakoj fotografiji kao što je prikazano na slici 14. Bušenje provrta se odradilo sa 3 parametra, 4 brzine rezanja, 4 posmaka i 4 stupnja istrošenosti alata, za sveukupno 64 kombinacije. Za svaku od njih je napravljeno 10 mjerenja, sa sveukupno 640 provrta. U [12] su obrađena 3 mjerenja za svaki provrt, dok je u ovom radu obrađeno ostalih 7 mjerenja. Provrti su slikani sa ulazne i izlazne strane, ali su obrađeni samo oni sa izlazne strane zbog teškoća u kvantificiranju delaminacije na slikama provrta sa ulazne strane. Razlika provrta ulazne i izlazne strane je prikazana na slici 15.



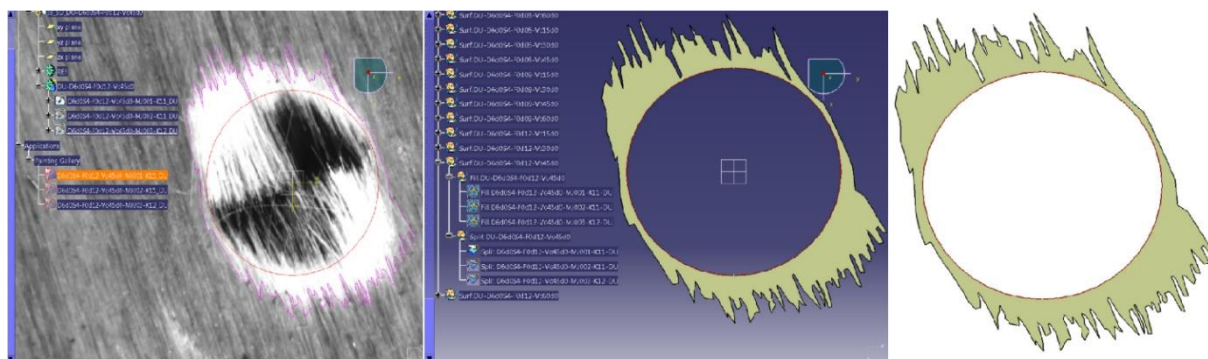
Slika 15. Izlazna (lijevo) i ulazna (desno) strana provrta





Slika 16. Kvantificiranje stupnja delaminacije


Nakon iscertavanja svih provrta, pomoću programa napisanog u Catia VBA alatu su izvučene značajke koje opisuju stanje delaminacije svakog provrta. Odaabrane su: površina delaminacije, opseg delaminacije, maksimalna udaljenost između točaka te srednja udaljenost između točaka. Na slici 17 je prikazan postupak određivanja površine delaminacije pomoću programa Catia.




Slika 17. Postupak određivanja površine delaminacije [12]

Slike 18, 19, 20 i 21 prikazuju ovisnost svake značajke o brzini rezanja  $vc$  i posmaku  $f$  podijeljenu po stupnju istrošenosti alata (S1...S4 gdje je S4 najistrošeniji alat). U daljnjem radu


koristimo samo značajku površine delaminacije dok druge odbacujemo zbog prevelikih nepravilnosti i preklapanja u prikazanim grafovima što ukazuje na lošu korelaciju. Također se u daljnjem radu koriste samo uzorci obrađeni u sklopu ovog rada zbog velikih različitosti uzrokovanih drugačijim načinom obrade.




Slika 18. Srednja udaljenost točaka



Slika 19. Opseg delaminacije



Slika 20. Površina delaminacije



**Slika 21. Maksimalna udaljenost između točaka**

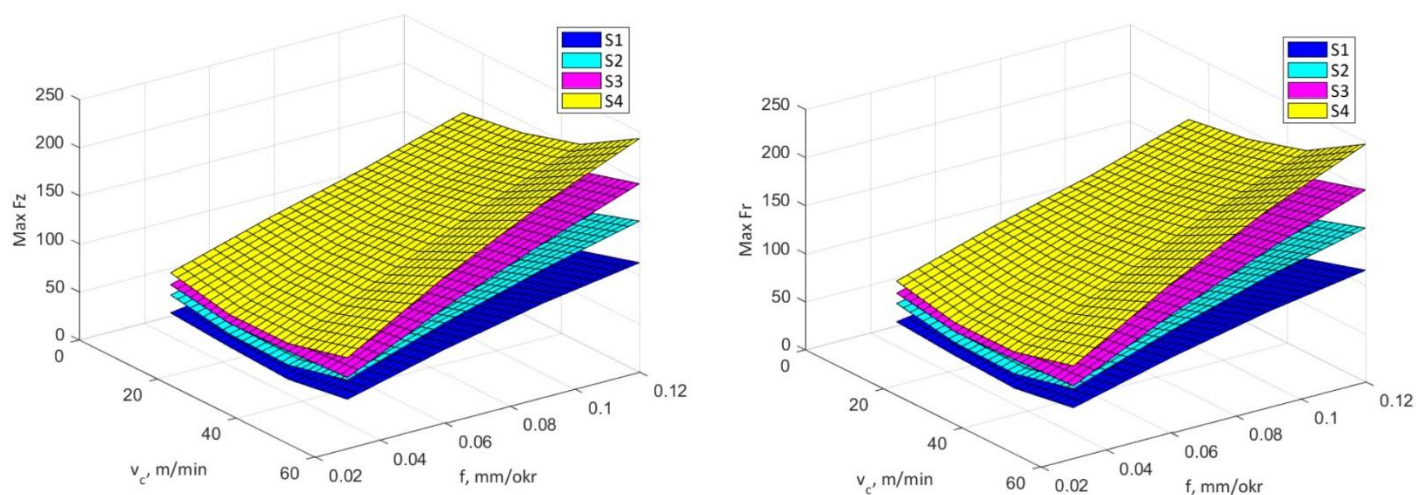
## 6.2 Sile rezanja

Dodatne značajke koje će nam poslužiti uz posmak i brzinu rezanja za procjenu stupnja delaminacije su značajke izvedene iz signala sila rezanja. Ispitivanjem korelacije značajki (eksperimentalno i pomoću programa Weka) je utvrđeno da značajke maksimalnih sila (Max F<sub>z</sub> i Max F<sub>r</sub>) te površine ispod njihovih krivulja (Surf F<sub>d</sub>, Surf F<sub>r</sub> i Surf F<sub>z</sub>) imaju dominantnu korelaciju sa stupnjem delaminacije, dok snage sila na frekvenciji vrtnje (SPL F<sub>y</sub>, SPL F<sub>x</sub>, SPR F<sub>x</sub>, SPR F<sub>y</sub> i SPR F<sub>z</sub>) imaju relativno mali utjecaj na kvalitetu klasifikacije stupnja delaminacije te ih zanemarujemo u ostatku rada.

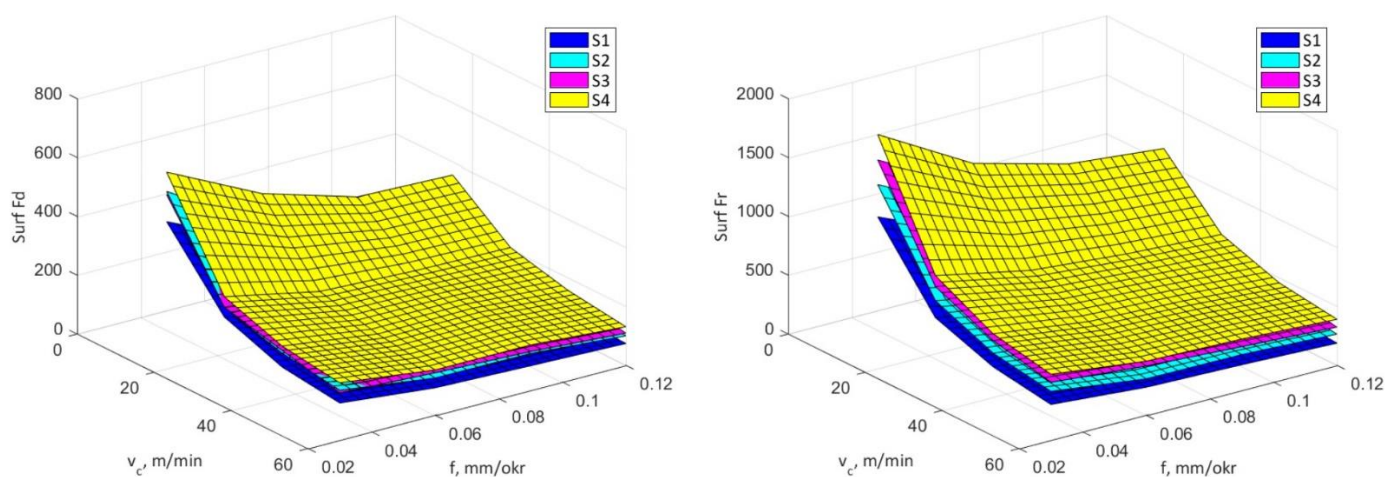


Tablica 3. Oznake i opisi značajki izdvojenih iz signala sila [12]

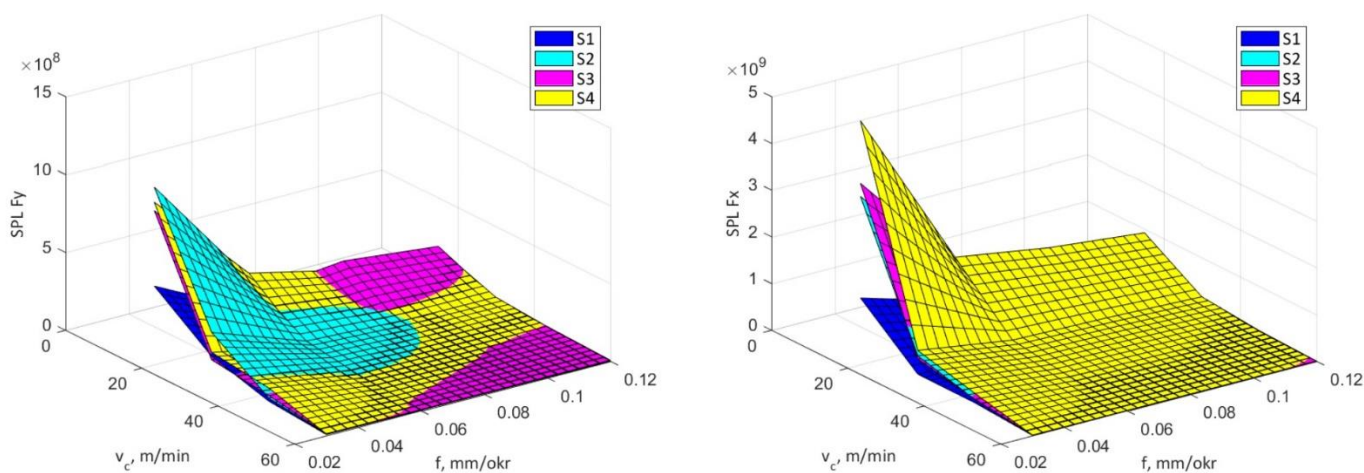
Oznaka	Opis	Oznaka	Opis
Max_Fr	Maksimalni iznos sile Fr	SPR_Fx	Snaga signala sile Fx na frekvenciji vrtnje
Max_Fz	Maksimalni iznos sile Fz	SPR_Fy	Snaga signala sile Fy na frekvenciji vrtnje
Surf_Fr	Površina ispod krivulje sile Fr	SPR_Fz	Snaga signala sile Fz na frekvenciji vrtnje
Surf_Fz	Površina ispod krivulje sile Fz	SPL_Fx	Snaga signala sile Fx na frekvenciji ošttrice
Surf_Fd	Površina ispod krivulje sile Fd	SPL_Fy	Snaga signala sile Fy na frekvenciji ošttrice
SPL_Fz			Snaga signala sile Fz na frekvenciji ošttrice



Slika 22. Značajke Max Fz i Max Fr




Slika 23. Značajke Surf Fd i Surf Fr



Slika 24. Značajke SPL Fy i SPL Fx

### 6.3 Stupanj istrošenosti alata

Istraživanja slična ovom su pokazala da u pravilu stupanj istrošenosti alata ima visoku korelaciju sa stupnjem delaminacije. Gaussove normalne distribucije stupnja delaminacije za svaki stupanj istrošenosti alata prikazane na slici 25 te njihove srednje vrijednosti dane u tablici 4.




**Slika 25. Normalna distribucija delaminacije po stupnjevima istrošenosti alata**

**Tablica 4. Srednje vrijednosti delaminacije po stupnju istrošenosti alata**


S1	S2	S3	S4
15.7	15.4	19.2	18.7

Prikazane distribucije jasno pokazuju da veza između stupnja istrošenosti alata i stupnja delaminacije postoji, odnosno da stupanj delaminacije raste s porastom stupnja istrošenosti alata. Također je vidljivo da postoje male razlike između stupnja delaminacije kod stupnjeva istrošenosti S1 i S2 te stupnjeva istrošenosti S3 i S4.

Od 7 uzoraka koji postoje za svaku kombinaciju parametara posmaka, brzine rezanja i stupnja istrošenosti je izračunata srednja vrijednost stupnja delaminacije na osnovu koje su napravljene slike 26, 27 i 28. Na slikama je vidljivo da postoje značajna preklapanja među ploham S1 i S2 te ploham S3 i S4 dok su plohe S2 i S3 jasno odvojene.




**Slika 26. Srednji iznos delaminacije po stupnjevima istrošenosti S1 i S2**




**Slika 27. Srednji iznos delaminacije po stupnjevima istrošenosti S3 i S4**






**Slika 28. Srednji iznos delaminacije po stupnjevima istrošenosti S2 i S3**

Zaključuje se da bi bilo povoljno reducirati broj stupnjeva istrošenosti na samo dva. Uzorci koji su pripadali stupnjevima S1 i S2 su dodjeljeni skupini S1, dok su uzorci iz stupnjeva S3 i S4 dodjeljeni skupini S2. Normalne distribucije su izračunate za korigirane stupnjeve istrošenosti alata i prikazane na slici 27. Plohe srednjih vrijednosti delaminacije su također ponovno izrađene i prikazane su na slici 28.



**Slika 29. Normalna distribucija delaminacije po korigiranim stupnjevima istrošenosti alata**




**Slika 30. Srednji iznos delaminacije po korigiranim stupnjevima istrošenosti S1 i S2**

Normalne distribucije i odvojenost plohi srednjih vrijednosti potvrđuju valjanost provedene korekcije broja stupnjeva istrošenosti te jasnu odvojenost stupnja delaminacije na dvije grupe. Ipak, na slici 29 se može uočiti da među individualnim uzorcima postoje značajna preklapanja

što je kombinacija utjecaja nehomogenosti u materijalu, ljudskih grešaka prilikom prikupljanja podataka i kvantificiranja stupnja delaminacije te drugih faktora.

#### 6.4 Klasifikacija stupnja delaminacije

Direktna aproksimacija stupnja delaminacije pomoću neuronske mreže se pokazala neprikladnom zbog velikog rasipanja i preklapanja podataka te nedovoljno kompleksne arhitekture upotrebljene neuronske mreže. Na osnovu slika 29 i 30 svaki uzorak je raspodjeljen u 2 skupine, D1 i D2. Ako je stupanj delaminacije određenog uzorka manji od 18, dodjeljen je skupini D1, a ako je veći od 18, dodjeljen je skupini D2. Kriterij raspodjele, stupanj delaminacije 18, je određen prema sjecištu dvaju normalnih distribucija sa slike 29. Za svaku kombinaciju posmaka i brzine rezanja postoji 28 uzoraka. Načinjena raspodjela stupnja delaminacije u 2 skupine je prikazana na primjeru jedne kombinacije posmaka i brzine rezanja.



Slika 31. Površina delaminacije po uzorku s posmakom 0,03 mm/okr i brzinom rezanja 45 m/min

#### 6.5 Izrada neuronske mreže

U nastavku za klasifikaciju upotrebljavamo neuronsku mrežu s jednim skrivenim slojem i sigmoidalnom aktivacijskom funkcijom za koju je kod napisan u programskom paketu Matlab.

Početne težine su nasumično uzimane iz normalne distribucije srednje vrijednosti 0 i standardne devijacije 1. U mrežu je također ugrađena i regularizacija težina koja pomaže da težine ostanu male po apsolutnoj vrijednosti što pridonosi generalizacijskim svojstvima neuronske mreže. Podaci za trening i učenje su raspodjeljeni u odnosu 50:50 zbog relativno male sveukupne količine podataka. Za ulazne značajke odabrani su posmak, brzinu rezanja, maksimalne iznose sila (Max\_Fr, Max\_Fz) te površine ispod krivulja maksimalnih sila (Surf\_Fz, Surf\_Fr, Surf\_Fd). Ulazne značajke su normalizirane što znatno poboljšava i ubrzava učenje mreže. Izlazne značajke su one koje želimo klasificirati, stupnjevi delaminacije D1 i D2. Podatci za učenje su pripremljeni tako da ako uzorak spada u skupinu D1, onda je vrijednost D1 stavljena na 1, a vrijednost D2 na 0. Pri testiranju neuronske mreže se smatralo da je mreža uzorak klasificirala u skupinu koja je odgovarala izlazu s većim iznosom. Parametri neuronske mreže prikazani u tablici 4 su dobiveni metodom pokušaja i pogreške gdje se zbog uštede vremena na manjem broju koraka testirala stabilnost i konzistentnost rasta klasifikacijske točnosti s zadanom kombinacijom parametara. Nakon što su okvirne vrijednosti parametara odabrane ovim putem, metoda pokušaja i pogreške je provedena s većim brojem koraka gdje je za određenu kombinaciju parametara gledana postignuta klasifikacijska točnost. Odabrana je kombinacija s kojom je postignuta maksimalna klasifikacijska točnost. Točnost je padala za brojeve skrivenih neurona manje i veće od odabranog. Zaključujemo da je broj od 16 skrivenih neurona dovoljno velik da omogući neuronskoj mreži opisivanje karakteristike problema, ali i dovoljno mali da ne uzrokuje pojavu *overfittinga*. Učenje neuronske mreže je provedeno uporabom algoritma povratnog prostiranja greške. Osnovne jednadžbe korištene pri primjeni ovog algoritma za promjenu težina neuronske mreže su:

$$v(n+1) = (1 - \eta * \lambda) * v(n) - \eta * \nabla_v + \alpha * \Delta v(n-1) \quad (6.1)$$

$$w(n+1) = (1 - \eta * \lambda) * w(n) - \eta * \nabla_w + \alpha * \Delta w(n-1) \quad (6.2)$$

$$\nabla_v = \frac{\partial E(n)}{\partial v} = \frac{\partial E(n)}{\partial y} \frac{\partial y}{\partial net_H} \frac{\partial net_H}{\partial v} \quad (6.3)$$

$$\nabla_w = \frac{\partial E(n)}{\partial w} = \frac{\partial E(n)}{\partial O} \frac{\partial O}{\partial net_O} \frac{\partial net_O}{\partial w} \quad (6.4)$$


gdje su:

$v$	matrica težina skrivenog sloja
$n$	broj koraka
$\eta$	parametar učenja
$\lambda$	parametar regularizacije
$\nabla_v$	matrica gradijenta težina skrivenog sloja
$\alpha$	parametar momentuma prvog reda
$\Delta v$	iznos promjene težina skrivenog sloja
$w$	matrica težina izlaznog sloja
$\nabla_w$	matrica gradijenta težina izlaznog sloja
$\Delta w$	iznos promjene težina izlaznog sloja
$E$	matrica pogreške
$y$	matrica izlaza skrivenih neurona
$net_H$	vektor suma ulaza skrivenih neurona
$O$	vektor izlaza mreže
$net_O$	vektor suma ulaza izlaznog sloja

**Tablica 5. Parametri neuronske mreže**

$\lambda$ (koeficijent regularizacije)	$\eta$ (parametar učenja)	$\alpha$ (parametar za momentum prvog reda)	Broj skrivenih neurona
<b>0.0001</b>	<b>0.01</b>	<b>0.4</b>	<b>16</b>


Na slici 30 je prikazana arhitektura upotrebljene neuronske mreže. Veze između neurona te stvarni broj neurona skrivenog sloja su izostavljeni radi preglednosti i jednostavnosti.



Slika 32. Arhitektura upotrebljene neuronske mreže

## 6.6 Rezultati učenja neuronske mreže

Neuronskom mrežom naučenom s prikazanim parametrima dobivena je klasifikacijska točnost od 79% na podacima za testiranje. Tijek testiranja je prikazan na slici 33 gdje je vidljivo da klasifikacijska točnost raste do 450. koraka učenja gdje ostaje na istoj klasifikacijskoj točnosti od 79%.



**Slika 33. Rast klasifikacijske točnosti po broju koraka do maksimalne vrijednosti**

## 7. Zaključak

U ovom radu je kvantificiran stupanj delaminacije na osnovu slika provrta napravljenih u polimernom kompozitu sa staklenim vlaknima. Određene su najbitnije značajke, izrađena je prikladna neuronska mreža te primjenjena za klasifikaciju stupnja delaminacije. Pokazano je da je moguće sa jednostavnom neuronskom mrežom s pomoću relativno malo podataka s velikom standardnom devijacijom dobiti prihvatljivu točnost klasifikacije. Ipak, stupanj delaminacije je podijeljena u samo dvije klase te bi bilo povoljnije dobiti direktnu aproksimaciju stupnja delaminacije ili barem klasificirati stupanj delaminacije s više preciznosti. U sklopu ovog završnog rada jedine dodatno mjerene značajke uzimane u obzir su bile mjerene sile, dok su signali struja motora, akustičnih emisija te vibracija izostavljeni zbog prevelikog obima posla. Slična istraživanja su pokazala da je često moguće stupanj delaminacije s velikom točnošću odrediti iz signala akustičnih emisija. Na osnovu toga se u nastavku ovog istraživanja s primjenom ostalih podataka očekuje točnija i robusnija klasifikacija stupnja delaminacije.



## 8. Literatura

- [1] T. Filetin, F. Kovačićek i J. Indof, Svojstva i primjena materijala, Zagreb: Fakultet strojarstva i brodogradnje, 2007.
- [2] G. Marić, Predavanja - Napredne tehnologije materijala - Postupci proizvodnje kompozita, Zagreb: FSB, 2013.
- [3] G. Marić, Materijali 2, Kompozitni materijali, Zagreb: FSB, 2012.
- [4] »[https://en.wikipedia.org/wiki/Composite\\_material](https://en.wikipedia.org/wiki/Composite_material),« [Mrežno].
- [5] »<http://www.princeton.edu/~ota/disk2/1988/8801/880106.PDF>,« Princeton University. [Mrežno].
- [6] »[http://www.substech.com/dokuwiki/doku.php?id=polymer\\_matrix\\_composites\\_introduction](http://www.substech.com/dokuwiki/doku.php?id=polymer_matrix_composites_introduction),« [Mrežno].
- [7] »[https://www.researchgate.net/figure/283308870\\_fig2\\_Figure-2-Typical-structure-of-Carbon-Fiber-Reinforced-Polymer-CFRP](https://www.researchgate.net/figure/283308870_fig2_Figure-2-Typical-structure-of-Carbon-Fiber-Reinforced-Polymer-CFRP),« [Mrežno].
- [8] M. Šercer, Predavanja - Proizvodnja kompozitnih tvorevina, Zagreb: FSB.
- [9] »<http://www.build-on-prince.com/glass-fiber.html#>,« [Mrežno].
- [10] S. Škorić, Predavanje Oblikovanje deformiranjem i obrada odvajanjem, Zagreb: FSB, 2009.
- [11] D. Majetić, B. Novaković i M. Široki, Umjetne neuronske mreže, Zagreb: Fakultet strojarstva i brodogradnje, 1998.
- [12] I. Bartolin, »Utjecaj trošenja alata i parametara obrade na raslojavanje pri bušenju kompozitnih materijala,« *Diplomski rad*, 2015.
- [13] »<https://vandaair.com/tag/composites/>,« [Mrežno].